

基于深度学习模型的颈椎 MR 图像脊髓及椎管自动测量

马超,冯小晨,杨家诚,林丽娜,张雪媛,王晓雯,任菲,邵成伟,曹鹏,曹凯

【摘要】 目的:探讨深度学习实现颈椎 MR 脊髓和椎管自动测量的可行性。方法:回顾性收集 558 例颈椎 MR 图像,以 8:1:1 的比例随机分为训练集($n=436$)、调优集($n=61$)和测试集($n=61$)。由一位低年资医师标注所有图像的椎管和脊髓,在测试集中测量脊髓最大受压程度、椎管最大狭窄程度、横截面积及压缩比,由一位主任医师审核所有结果后作为金标准。另一位高年资医师在测试集中进行测量作为人工组结果。以 Swin Transformer 为骨干网络的深度学习模型进行的分割和测量作为模型组结果。采用 Dice 相似系数(DSC)、交并比(IoU)评价模型分割性能。使用组内相关系数(ICC)、Bland-Altman 散点图比较各组结果一致性。结果:测试集中,深度学习模型分割脊髓(横轴面、矢状面)和椎管(矢状面)的 DSC 值(%)为 93.10 ± 0.57 、 94.60 ± 0.09 、 86.17 ± 0.22 ,IoU 值(%)为 87.09 ± 1.00 、 89.76 ± 0.17 、 75.70 ± 0.34 。人工组、模型组和金标准的 ICC 值为 $0.770 \sim 0.945$,模型组与金标准的组间 ICC 值为 $0.782 \sim 0.913$,人工组与金标准的组间 ICC 值为 $0.692 \sim 0.903$,三组之间的差异具有统计学意义($P < 0.001$)。结论:深度学习模型对颈椎 MR 椎管和脊髓的分割测量具有较高准确性。

【关键字】 磁共振成像;颈椎;深度学习;自动分割;自动测量

【中图分类号】 R445.2;R-05 **【文献标识码】** A **【文章编号】** 1000-0313(2024)11-1514-07

DOI:10.13609/j.cnki.1000-0313.2024.11.014

开放科学(资源服务)标识码(OSID):



Automatic measurement of spinal cord and canal on cervical MRI images based on deep learning models

MA Chao, FENG Xiao-chen, YANG Jia-cheng, et al. Department of Diagnostic Radiology, the First Affiliated Hospital of PLA Naval Medical University, Shanghai 200433, China

【Abstract】 Objective: To explore the feasibility of automatic measurement of spinal cord and canal in cervical MR using deep learning. **Methods:** 558 cases of cervical spine MR images were retrospectively collected and randomly divided into training set ($n=436$), validation set ($n=61$), and test set ($n=61$) at 8:1:1. The spinal canal and spinal cord of all images were labeled by a junior physician, and the maximum spinal cord compression, maximum canal compromise, transverse area, and compression ratio were measured in the test set. All results were then reviewed by a chief physician as the gold standard. Another senior physician conducted measurements on the test set as the manual group results. A deep learning model, utilizing Swin Transformer as the backbone network, was employed for segmentation and measurement, contributing to the model group results. Evaluation of the model's segmentation performance was conducted using dice similarity coefficient (DSC) and Intersection-over-Union (IoU). Consistency was compared across groups, including the junior physician, chief physician, manual group, and the deep learning model, using Intraclass correlation coefficient (ICC) and Bland-Altman scatter plots. **Results:** In the test set, the DSC values (%) for the deep learning model segmentation of the spinal cord (axial and sagittal planes) and vertebral canal (sagittal plane) were 93.10 ± 0.57 , 94.60 ± 0.09 , and 86.17 ± 0.22 , respectively. The IoU values (%) were 87.09 ± 1.00 , 89.76 ± 0.17 , and 75.70 ± 0.34 , respectively. The ICC values of the manual group, model group, and gold standard ranged from 0.770 to 0.945. The ICC values of the model group and gold standard ranged from 0.782 to 0.913; the ICC values of the manual group and gold standard ranged from 0.692 to 0.903. The differ-

作者单位:200433 上海,中国人民解放军海军军医大学第一附属医院放射诊断科(马超、冯小晨、杨家诚、林丽娜、邵成伟、曹凯);200003 上海,中国人民解放军海军军医大学第二附属医院脊柱外科(曹鹏);401329 重庆,重庆知见生命科技有限公司(张雪媛、王晓雯);100190 北京,中国科学院计算技术研究所处理器芯片全国重点实验室(任菲)

作者简介:马超(1991-),男,新疆克拉玛依人,本科,住院医师,主要从事人工智能新技术应用及骨肌影像学研究。

通讯作者:曹凯, E-mail: mdkaicao163@163.com

基金项目:国家自然科学基金面上项目(82372045);上海市自然科学基金面上项目(23ZR1478400)

ences between the three groups were statistically significant ($P < 0.001$). **Conclusion:** The deep learning model demonstrates high accuracy in the segmentation and measurement of spinal cord and canal in cervical MR.

【Key words】 Magnetic resonance imaging; Cervical vertebral; Deep learning; Auto-segmentation; Auto-measurement

脊髓型颈椎病(cervical spondylotic myelopathy, CSM)是骨质、椎间盘、韧带等退行性改变导致脊髓受压引起脊髓功能障碍的疾病^[1]。一项基于影像学评估的研究表明,无症状脊髓压迫的患病率为 24.2%,由于缺乏早期干预,从而产生进行性脊髓损伤,导致生活质量下降,严重时甚至会出现身体残疾^[2-3]。因此,CSM 的早期诊断尤为重要。

脊髓压迫与 CSM 的严重程度密切相关,颈椎 MR 由于软组分分辨率高,对韧带、椎管、脊髓等结构显示清晰,并且脊髓生长在椎管内,在 T₂WI 序列中脊髓的低信号与脑脊液的高信号形成明显的信号差异,从而易于脊髓和椎管的测量。颈椎 MR 图像中测量脊髓及椎管,不仅可以判断脊髓受压程度,为 CSM 的评估提供量化依据^[4],并且量化数据可以为保守治疗的患者在后续的随访过程中提供前后对比的基线数据。然而,由于脊髓和椎管的测量严重依赖于人工,测量步骤单一、计算公式繁琐、费时费力,因此在实际临床工作中应用较少,实现在颈椎 MR 图像中脊髓和椎管的自动测量能够减少医师不必要的简单劳动,提高诊断和书写报告的效率。

基于卷积神经网络(convolutional neural networks, CNNs)构建的深度学习模型目前已应用于颈椎和腰椎 MR 图像中各组织结构的自动分割^[5-7]。本研究拟探讨基于深度学习模型实现颈椎 MR 图像脊髓和椎管自动分割及测量的可行性。

材料与方 法

1. 数据收集

PACS 系统回顾性连续收集 2021 年 1 月—2021 年 12 月于本院健康管理中心行颈椎 MR 平扫的被检者 614 人。排除标准(图 1):①检查前有颈椎手术等治疗史;②有颈椎肿瘤、外伤、感染等病史;③不能配合检查、图像质量不佳;④被检者图像序列不全。最终 558 例被检者的 1752 张 MR 图像(矢状面 T₂WI 图像 1194 张、横轴面 T₂WI 图像 558 张)纳入研究。其中男 339 例,女 219 例,年龄

20~86 岁,平均(49.01±11.01)岁。本研究经上海长海医院伦理委员会批准,免除患者知情同意书。数据集图像匿名化后,按照 8:1:1 比例随机分为训练集(n=436)、调优集(n=61)和测试集(n=61)。

2. 数据标注与测量

将所有数据集中,颈椎矢状面 T₂WI 和横轴面 T₂WI 的 DICOM 格式图像转换为 PNG 图像。由一位低年资放射科主治医师(骨肌亚专业 4 年)使用 labelme(v5.1.1)软件对颈椎矢状面和横轴面图像上椎管和脊髓进行标注。具体标注步骤及标准如下:①在矢状面 T₂WI 图像上进行脊髓和椎管的标注,选择脊髓及椎管显示的最大层面,C2~C3 椎体水平为上界,C7~T1 椎体水平为下界;脊髓标注的前后界为脊髓与脑脊液交界处脊髓侧前后缘;椎管标注的前后界为硬脊膜前后缘,不包括韧带、椎体、椎间盘、硬膜外脂肪。②在矢状面图像中,对 C3~C7 椎体骨皮质低信号边缘的四个端点进行了关键点标注,避开邻近韧带、椎间盘等结构,并采用不同的标签进行标记。例如,将 C3 椎体的前上、前下、后上、后下端点分别标注为关键点 1、2、3、4;接着对 C4 椎体的前上、前下、后上、后下端点标注为关键点 5、6、7、8;而后按照顺序对 C5、C6、C7 的关键点进行标注。③在横轴面 T₂WI 图像上进行脊髓的标注,选择矢状面 T₂WI 图像上脊髓受压最窄层面水平的横轴面 T₂WI 图像,沿脊髓与脑脊液交

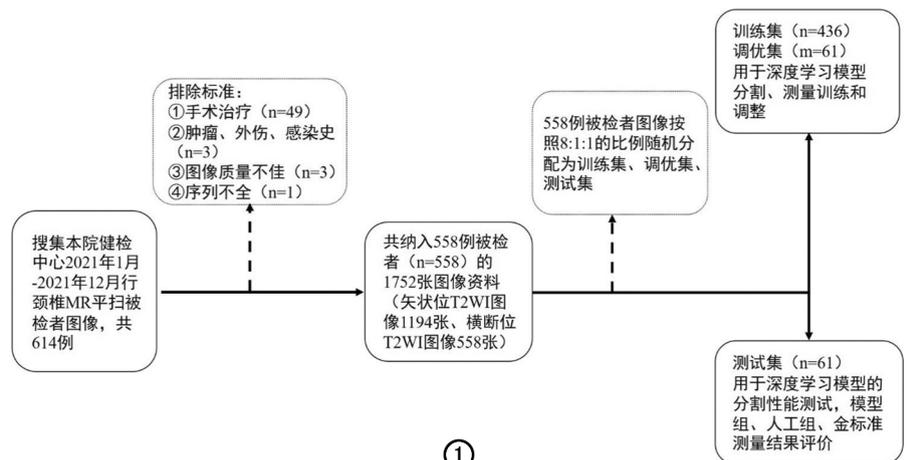


图 1 研究对象纳排流程图。

界处脊髓侧边缘标注包含脊髓的图像,不包括神经根。在测试集中对椎管和脊髓进行测量、计算。脊髓及椎管的测量根据 Alina 等^[8]在研究中描述的测量方法(图 2),在矢状面 T₂WI 图像上测量并计算脊髓最大受压程度(maximum spinal cord compression, MSCC)、椎管最大狭窄程度(maximum canal compromise, MCC),在横轴面 T₂WI 图像上测量并计算横截面积(transverse area, TA)及压缩比(compression ratio, CR),CR 指前后径与横径之比。MSCC 和 MCC 具体计算公式如下:

$$\text{MSCC}(\%) = [1 - 2d_i / (d_a + d_b)] \times 100\% \quad (1)$$

$$\text{MCC}(\%) = [1 - 2D_i / (D_a + D_b)] \times 100\% \quad (2)$$

其中, d_i 、 D_i 分别定义为脊髓和椎管最窄层面的前后径, d_a 、 D_a 分别定义为脊髓和椎管最窄层面上方正正常椎体节段中点前后径, d_b 、 D_b 分别定义为脊髓和椎管最窄层面下方正常椎体节段中点前后径。TA 为脊髓最窄层面横截面积(mm^2); CR 为脊髓最窄层面最小前后径与横径之比。

低年资放射科主治医师的标注及测量计算结果,由一位放射科主任医师(阅片经验 25 年)进行复核。

如有不一致的情况,以放射科主任医师的标注与测量结果为金标准。另一名高年资放射科主治医师(骨肌亚专业 10 年)在测试集中进行测量并计算,结果定义为人工组。

3.模型构建

模型构建包括三个部分(图 3):①椎管和脊髓分割模型;②颈椎矢状面图像椎体关键点检测模型;③颈椎 MR 图像中 MSCC、MCC、CR 和 TA 的自动测量模型。

采用基于阈值分割的方法去除背景区域,提取图像中的感兴趣区(region of interest, ROI)。非组织区域的背景部分灰度值为 0,组织区域的灰度值为 0~200,其中,组织区域的外围轮廓像素灰度值通常高于 100。首先,将阈值设为 50 对图像做二值化处理,然后计算所有区域的外接矩形,以便准确获取图像中的组织区域。对于矢状面图像,组织区域即为 ROI。而对于横轴面图像,脊髓区域位于组织的中心部分。以外接矩形的中心为基准,提取一个尺寸为 200×200 像素的图像块,作为横轴面图像的 ROI。然后将提取的所有 ROI 统一缩放为 512×512 像素大小,输入分割模

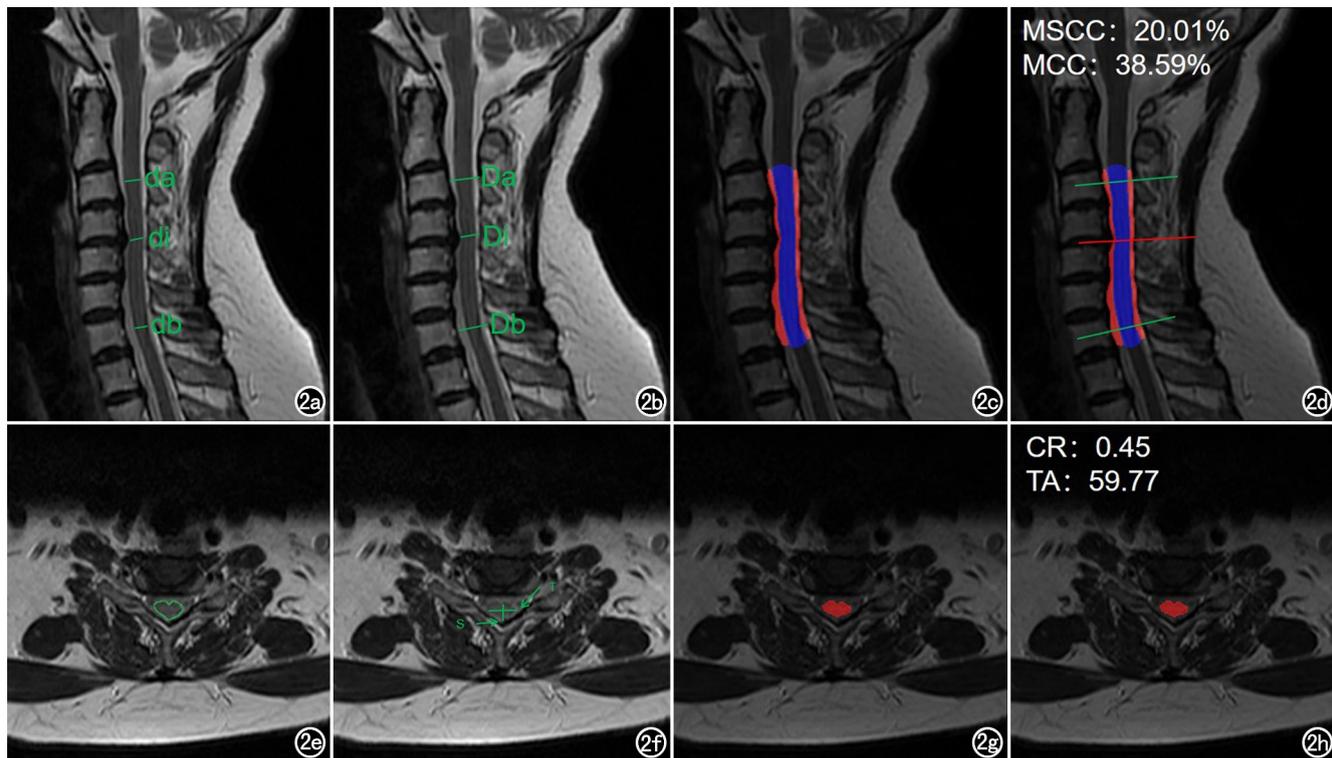


图 2 测试集病例 T₂WI 矢状面和横轴面的人工测量方法和深度学习模型测量方法。a) MSCC 的人工测量方法,分别测量脊髓最窄层面前后径(d_i)和脊髓最窄层面上方、下方正常椎体节段中点前后径(d_a 、 d_b); b) MCC 的人工测量方法,分别测量椎管最窄层面前后径(D_i)和椎管最窄层面上方、下方正常椎体节段中点前后径(D_a 、 D_b); c) 分割椎管狭窄最明显层面矢状面图像的脊髓和椎管; d) 自动选择脊髓和椎管的前后径最小值水平、C3 和 C7 的脊髓椎管平均宽度水平测量前后径,计算得到 MSCC 和 MCC; e) TA 的人工测量方法; f) CR 的人工测量方法,分别测量横径(T)和前后径(S); g) 分割椎管狭窄最明显层面横轴面图像的脊髓; h) 自动测量分割区域的横径、前后径,自动检测分割区域像素面积,计算得到 CR 和 TA。

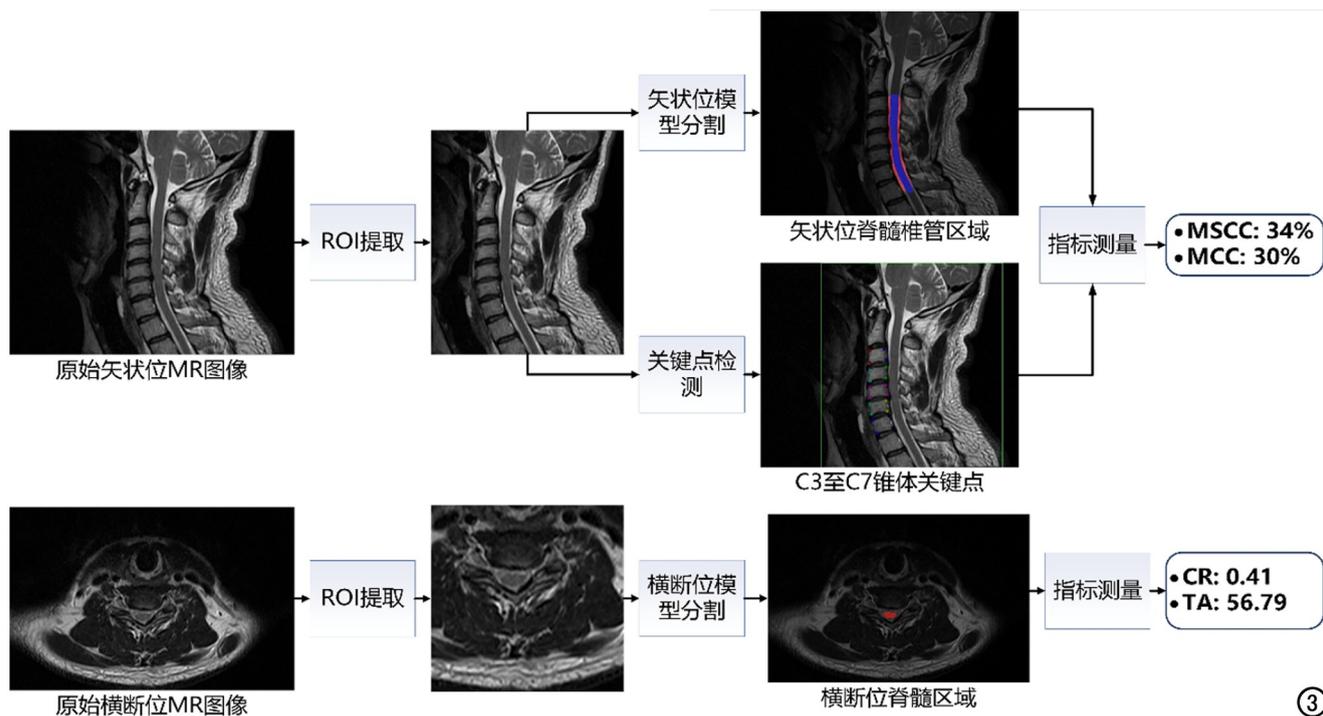


图3 颈椎MR图像指标自动测量的方法流程图。

型进行训练和检测。分割模型为 UperNet^[9] 语义分割模型,它是基于特征金字塔网络的图像语义分割模型,其特点是在每个像素点上预测其所属的类别。为了提高模型的分割效果,将 Swin Transformer^[10] 作为骨干网络嵌入到 UperNet 模型中。Swin Transformer 是基于 Transformer 结构的通用骨干网络,其特点是在保持较高计算效率的同时,能够实现强大的特征抽取能力。Swin Transformer 以自注意力机制为核心,能够有效地捕捉图像中不同区域之间的长距离依赖关系,这对于理解医学图像中的解剖结构和不同结构之间的相关性至关重要。此外,它通过分阶段的多尺度特征融合机制,能够有效地整合不同尺度的信息,从而提高模型对于不同尺寸下结构的理解能力。以层次化的注意力机制替代了传统的平铺式自注意力机制,极大地减少了参数量,提高了模型的效率,降低了计算和内存消耗,这使得 Swin Transformer 更适用于在资源受限的环境下实现高效的分割任务。通过将 Swin Transformer 作为骨干网络,UperNet 能够更好地捕捉到 ROI 中的细节信息,从而实现更精确的分割效果。

为了测量 MSCC 和 MCC 指标,需要定位矢状面图像中 C3~C7 各个椎体的位置。本研究采用高分辨率网络(high-resolution net, HRNet)^[11] 进行 C3~C7 各椎体四个端点的关键点定位。HRNet 是一种用于人体姿态估计的深度卷积神经网络模型。它通过重复的多尺度融合来提高特征图的空间分辨率,并在不同

层次上同时保留高分辨率和低分辨率特征,大幅度提高检测模型的精度,可更好地测量 MSCC 和 MCC 指标。损失函数为均方误差(mean squared error, MSE) 损失函数,用于比较预测热图和真实值热图之间的差异。真实值热图和预测热图均为 20 通道的图像,其中每个通道代表一类关键点。对于每个关键点,以其位置为中心,采用高斯分布的方式进行扩展。

基于矢状面 T₂WI 图像分割脊髓、椎管及 C3~C7 各椎体关键点的定位信息,进行 MSCC 和 MCC 的指标测量。首先,根据脊髓和椎管的分割结果获得它们的二值化区域。随后,将脊髓和椎管区域沿着各节椎体后两个端点的垂直方向分成多个层次。对于每个层次,沿着上述垂直方向计算脊髓和椎管的宽度,从而得到了每个层次的脊髓宽度和椎管宽度。接着,根据关键点识别的坐标信息,定位 C3 椎体和 C7 椎体的区域,并将 C3 椎体和 C7 椎体区域的宽度取平均值作为 C3 和 C7 脊髓椎管的平均宽度。最后,分别选取每层次中脊髓宽度和椎管宽度的最小值,并结合 C3 和 C7 的脊髓椎管平均宽度计算得到 MSCC 和 MCC。

基于横轴面 T₂WI 图像分割脊髓并进行 CR 和 TA 的指标测量。首先,根据脊髓分割结果,获取脊髓的最小外接矩形,并以矩形的长度作为脊髓的横径。随后,对脊髓的分割轮廓进行凸包检测,得到脊髓的前后径长度。由此,脊髓的横径和前后径的比值即为 CR 值。然后,基于脊髓的分割结果得到脊髓的像素面积,再根据 DICOM 文件中的像素间距信息,获得真

实的脊髓面积作为 TA 值。

4. 模型评价

使用 Dice 相似系数 (dice similarity coefficient, DSC) 和交并比 (intersection-over-union, IoU) 进行模型分割性能评价, 计算公式分别为:

$$DSC(A, B) = 2 \times |A \cap B| / (|A| + |B|) \quad (3)$$

$$IoU(A, B) = |A \cap B| / |A \cup B| \quad (4)$$

其中, A 为放射科医师在矢状面 T₂WI 图像和横轴面 T₂WI 图像上标注的脊髓和椎管的体素数, B 为模型在矢状面 T₂WI 图像和横轴面 T₂WI 图像上分割的脊髓和椎管体素数。DSC 是衡量两个体素集合之间相似性的度量指标, IoU 是衡量两个体素集合重合程度的度量指标, 取值范围为 0~1, 数值越大, 代表两个集合之间的相似性和重合程度越高。

5. 统计学方法

使用 python 3.7.13 软件进行统计学分析。符合正态分布的计量资料以均数 ± 标准差 (mean ± SD) 来表示。对训练集、调优集、测试集的 IoU 和 Dice 值对分割模型进行交叉验证, 用于评估模型的分割能力。使用组内相关系数 (intraclass correlation coefficient, ICC)、Bland-Altman 散点图评估人工组、模型组与金标准之间的一致性, 置信区间取 95% (95% CI)。以 P < 0.05 为差异具有统计学意义。

结果

1. 模型分割结果评价

在训练集、调优集及测试集中, 模型对矢状面 T₂WI 图像脊髓和椎管分割结果的 DSC 值和 IoU 值见表 1。

2. 各组测量结果的一致性分析

人工组、模型组和金标准测得脊髓和椎管的测量结果见表 2。运用 Bland-Altman 散点图分析人工组、

模型组与金标准的一致性 (图 4)。模型组与金标准的 ICC 值为 0.782~0.913, 人工组与金标准的 ICC 值为 0.692~0.903。

讨论

CSM 容易引起椎管狭窄、脊髓受压, 从而导致静态或动态的脊髓损伤。脊髓的受压程度是手术决策的重要参考因素。在 CSM 的诊断中, MRI 可以清晰显示椎间盘、韧带、椎管、脊髓等结构, 提供了丰富的诊断信息和定量参数。然而, 放射科医生通常依靠主观定性诊断 CSM, 而定量诊断则由于测量工具限制以及测量过程的耗时耗力, 很少在实际工作中使用。本研究采用了以 Swin Transformer 为网络主干的深度学习模型, 在颈椎矢状面和横轴面 T₂WI 图像上进行椎管和脊髓的自动分割, 并自动测量椎管和脊髓的径线与面积, 得到 MCC、MSCC、CR、TA 四个与椎管狭窄、脊髓压迫相关的指标。

相关研究^[8]表明, MCC 和 MSCC 测量的观察者内部和观察者间的 ICC 分别为 0.88 ± 0.1、0.75 ± 0.04 (MCC) 和 0.76 ± 0.08、0.79 ± 0.09 (MSCC)。MCC 和 MSCC 在非外伤脊髓损伤的患者中比急性外伤性脊髓损伤的患者更具可靠性, 并且与临床严重程度相关性更好。测量 CR 和 TA 可以评估脊髓受压程度, 是反应脊髓压迫的敏感指标^[12]。以往研究^[8]显示, CR 和 TA 测量的观察者内部和观察者间的 ICC 分别为 0.82 ± 0.13、0.80 ± 0.05 (CR) 和 0.92 ± 0.07、0.86 ± 0.03 (TA)。TA 比 CR 具有更好的一致性, 主要原因是 CR 在脊髓非对称性压迫中的应用受到限制, 而 TA 表现更加可靠。有报道脊髓 TA 与颈椎脊髓病的临床严重程度之间有一致相关性^[13]。在本研究人工组、模型组和金标准的 MCC、MSCC、CR 和 TA 的测量结果

表 1 分割模型颈椎 MR 椎管和脊髓的 DSC 值和 IoU 值

分割参数	训练集	调优集	测试集
DSC			
矢状面-脊髓	95.00 ± 0.08	94.96 ± 0.03	94.60 ± 0.09
矢状面-椎管	86.84 ± 0.09	86.65 ± 0.33	86.17 ± 0.22
横轴面-脊髓	94.30 ± 0.37	93.47 ± 0.88	93.10 ± 0.57
IoU			
矢状面-脊髓	90.47 ± 0.16	90.41 ± 0.06	89.76 ± 0.17
矢状面-椎管	76.74 ± 0.15	76.44 ± 0.52	75.70 ± 0.34
横轴面-脊髓	89.23 ± 0.66	87.76 ± 1.56	87.09 ± 1.00

表 2 人工组、模型组和金标准脊髓和椎管的测量结果

测量值	人工组	模型组	金标准	ICC	95% CI	P 值
MCC	0.273 ± 0.097	0.224 ± 0.083	0.237 ± 0.082	0.945	0.92~0.96	<0.001
MSCC	0.145 ± 0.074	0.176 ± 0.072	0.186 ± 0.078	0.770	0.65~0.85	<0.001
CR	0.466 ± 0.084	0.448 ± 0.076	0.423 ± 0.075	0.916	0.87~0.95	<0.001
TA (cm ²)	79.60 ± 10.93	64.83 ± 9.86	63.66 ± 11.63	0.917	0.87~0.95	<0.001

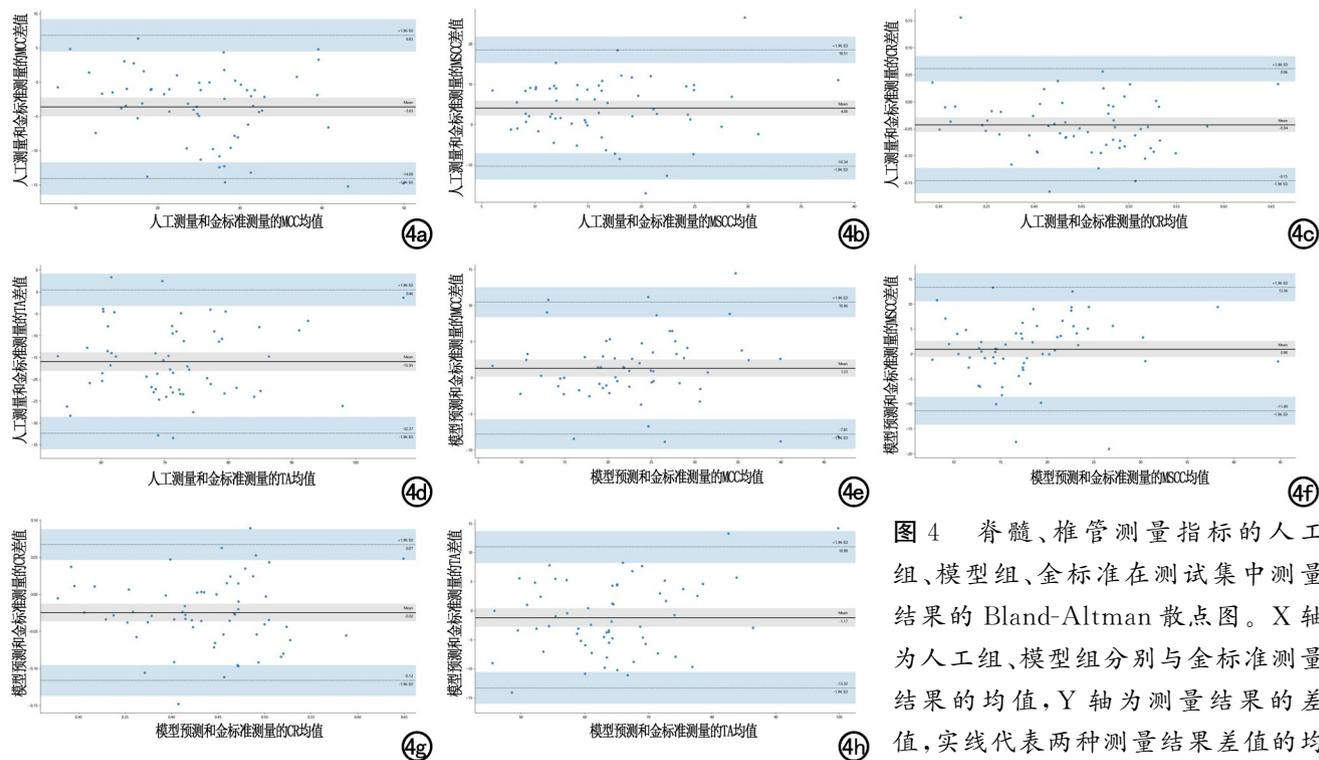


图 4 脊髓、椎管测量指标的人工组、模型组、金标准在测试集中测量结果的 Bland-Altman 散点图。X 轴为人工组、模型组分别与金标准测量结果的均值, Y 轴为测量结果的差值, 实线代表两种测量结果差值的均

数, 上、下两条虚线代表 95% 置信区间的上下界限。a) 人工组 MCC 测量结果; b) 人工组 MSCC 测量结果; c) 人工组 CR 测量结果; d) 人工组 TA 测量结果; e) 模型组 MCC 测量结果; f) 模型组 MSCC 测量结果; g) 模型组 CR 测量结果; h) 模型组 TA 测量结果。

中, 模型组的表现更优于人工组, 与金标准一致性更高, 然而在 MSCC 的测量中, 人工组、模型组和金标准的一致性低于其他三个指标。分析其主要原因是在测量过程中脊髓上下正常区域前后径的最大值, 人工与模型选择有差异, 从而导致计算结果出现不一致。

随着人工智能发展, 深度学习应用在脊椎医学影像中的识别、分割、测量受到了国内外学者的广泛关注。在 X 线和 CT 方面, Kim 等^[14] 使用 MDR2-Unet 模型在胸椎和腰椎 X 线矢状面图像上实现了椎体的自动分割和椎体压缩比的测量。结果显示, 模型测量结果与专家测量的结果呈良好的相关性(相关系数为 0.929), 模型的分割性能良好, 椎体压缩比的测量精度和可靠性较高。Alukaev 等^[15] 基于 3D U-Net 模型, 实现了胸椎 CT 三维图像中椎体和椎间盘高度及 Cobb 角的自动测量。该模型的 DSC 值为 0.9, 与人工测量结果的相关系数分别为 0.943、0.928 和 0.996。在 MRI 方面, Nozawa 等^[16] 使用三种深度学习模型测量退行性脊椎病受压脊髓的横截面积(CSA), 每个模型的分割 Dice 系数约为 0.90, 分割效果良好。研究还发现, 脊髓 CSA 比率与神经症状之间的相关性较弱但显著(Spearman's 相关系数为 0.38, $P = 0.007$)。Zhang 等^[17] 开发了 BiaoqueNet 模型, 在腰椎 MR 的 T₂WI 图像上用于腰椎间盘退变高精度定量。该模型

在腰椎整体、椎体、椎间盘的分割性能表现优秀, mDice 值和 mIoU 值均在 90% 以上。此外, 对于椎间盘高度(DH)、椎间盘高度指数(DHI)和椎间盘高径比(HDR)的测量, 模型和人工测量结果也表现出良好一致性(DH、DHI 和 HDR 的 ICC 值分别为 0.954、0.908 和 0.917)。

本研究模型相较于传统的卷积神经网络, 利用自注意力机制, 实现了全局建模能力, 能够更好地捕捉颈椎 MR 图像分割任务中的全局上下文信息, 理解不同区域之间的关联性和语义连贯性, 从而提高分割的准确性和鲁棒性。同时, 模型通过采用 UperNet 模型多层的特征融合策略, 整合来自不同层级的特征, 从而更准确地推断像素的语义类别和边界, 进一步提升了分割结果的质量。

本研究仍存在一些不足之处。首先, 在本研究中, 虽然模型的分割结果与专家的金标准结果具有较好的一致性, 但仍存在一定的测量偏差。模型测量结果比人工测量相比, MCC、MSCC 偏小, 而 CR 和 TA 偏大。究其原因可能是蛛网膜、硬脊膜存在一定的厚度, 解剖结构模糊, 对椎管、脑脊液、脊髓边界的界定存在一定的影响。尽管在测量中已经设定了测量的边界, 但由于输入图像的边界清晰度不足, 使得对边界的处理能力不足, 从而影响了测量的结果。未来的研究可以收

集数量更多、分辨率更高的图像,以提高测量的准确性。其次,本研究仅选择了 T₂WI 矢状面图像中显示脊髓最大层面的图像进行分割、测量,可能会导致 MCC 和 MSCC 对于偏心性受压脊髓的测量结果与实际椎管和脊髓受压情况存在一定差异。这是由于图像扫描层厚的限制,脊髓边缘在 T₂WI 矢状面图像中很难准确界定椎管和脊髓的边界。在后续的研究中,可以尝试使用 T₂WI 横轴面图像进行 MCC 和 MSCC 的测量。最后,本研究基于单中心健康体检人群开展,未能对模型泛化性及分类性能进行验证。然而,本研究所开发的深度学习模型具备了有效分割和自动测量椎管与脊髓的能力,这为后续进行多中心多参数的临床诊断分类模型研究,提供了高效测量工具。

总之,本研究的深度学习模型在颈椎 MR 矢状面 T₂WI 及横轴面 T₂WI 图像上展现出了准确的分割能力,能够对椎管和脊髓的径线和面积进行准确的测量。在将来进一步的研究中,需要增加样本数量、提高图像质量,并进行外部验证,以进一步提高模型性能及泛化能力,为临床诊断和治疗提供更准确的参考依据。

参考文献:

- [1] Nouri A, Tetreault L, Singh A, et al. Degenerative cervical myelopathy: Epidemiology, genetics, and pathogenesis[J]. *Spine*, 2015, 40(12): E675-E693.
- [2] Smith Sam S, Stewart Max E, Davies Benjamin M, et al. The prevalence of asymptomatic and symptomatic spinal cord compression on magnetic resonance imaging: A systematic review and meta-analysis[J]. *Global Spine J*, 2021, 11(4): 597-607.
- [3] Behrbalk Eyal, Salame Khalil, Regev Gilad J, et al. Delayed diagnosis of cervical spondylotic myelopathy by primary care physicians [J]. *Neurosurg Focus*, 2013, 35(1): E1-E6.
- [4] Arvin B, Kalsi-Ryan S, Mercier D, et al. Preoperative magnetic resonance imaging is associated with baseline neurological status and can predict postoperative recovery in patients with cervical spondylotic myelopathy[J]. *Spine*, 2013, 38(14): 1170-1176.
- [5] 朱逸峰, 赵凯, 郭丽, 等. 基于深度学习模型实现颈椎 MR 图像上各结构的自动分割[J]. *放射学实践*, 2021, 36(12): 1558-1562.
- [6] 段硕, 崔维, 张舵, 等. 神经网络模型自动分割测量颈椎 MRI 椎间盘及深层伸肌面积的可行性研究[J]. *中国脊柱脊髓杂志*, 2021, 31(9): 833-840.
- [7] 郭丽, 赵凯, 朱逸峰, 等. 使用 U-Net 深度学习网络对腰椎矢状 T₂WI 图像自动分割的可行性研究[J]. *放射学实践*, 2022, 37(2): 229-234.
- [8] Karpova A, Arun R, Davis AM, et al. Reliability of quantitative magnetic resonance imaging methods in the assessment of spinal canal stenosis and cord compression in cervical myelopathy[J]. *Spine*, 2013, 38(3): 245-252.
- [9] Xiao T, Liu Y, Zhou B, et al. Unified perceptual parsing for scene understanding[C]. *Proceedings of the European conference on computer vision (ECCV)*, 2018: 418-434.
- [10] Liu Z, Lin Y, Cao Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]. *Proceedings of the IEEE/CVF international conference on computer vision*, 2021: 10012-10022.
- [11] Sun K, Xiao B, Liu D, et al. Deep high-resolution representation learning for human pose estimation [C]. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2019: 5693-5703.
- [12] Nouri A, Martin AR, Mikulis D, et al. Magnetic resonance imaging assessment of degenerative cervical myelopathy: a review of structural changes and measurement techniques[J]. *Neurosurg Focus*, 2016, 40(6): E5-E21.
- [13] Morio Y, Teshima R, Nagashima H, et al. Correlation between operative outcomes of cervical compression myelopathy and mri of the spinal cord[J]. *Spine*, 2001, 26(11): 1238-1245.
- [14] Kim DH, Jeong JG, Kim YJ, et al. Automated vertebral segmentation and measurement of vertebral compression ratio based on deep learning in X-ray images[J]. *J Digit Imaging*, 2021, 34(4): 853-861.
- [15] Alukaev D, Kiselev S, Mustafaev T, et al. A deep learning framework for vertebral morphometry and Cobb angle measurement with external validation[J]. *Eur Spine J*, 2022, 31(8): 2115-2124.
- [16] Nozawa K, Maki S, Furuya T, et al. Magnetic resonance image segmentation of the compressed spinal cord in patients with degenerative cervical myelopathy using convolutional neural networks[J]. *Int J Comput Assist Radiol Surg*, 2023, 18(1): 45-54.
- [17] Zheng HD, Sun YL, Kong DW, et al. Deep learning-based high-accuracy quantitation for lumbar intervertebral disc degeneration from MRI[J]. *Nat Commun*, 2022, 13(1): 841-852.

(收稿日期: 2023-12-15 修回日期: 2024-04-30)